

# 基于卷积神经网络的超分辨率失真控制图像重构研究

舒忠<sup>1,2</sup>, 郑波儿<sup>1</sup>

(1.荆楚理工学院 电子信息工程学院, 湖北 荆门 448000;

2.荆门融媒网络科技有限公司, 湖北 荆门 448000)

**摘要:** **目的** 解决超分辨率图像重构模型中存在的功能单元之间关联性差, 图像色度特征提取完整性不强、超分辨率重构失真控制和采样过程残差控制偏弱等问题。**方法** 通过在卷积神经网络模型引入双激活函数, 提高模型中各功能单元之间的兼容连接性; 引用密集连接卷积神经网络构建超分辨率失真控制单元, 分别实现对 4 个色度分量进行卷积补偿运算; 将残差插值函数应用于上采样单元中, 使用深度反投影网络规则实现超分辨率色度特征插值运算。**结果** 设计的模型集联了内部多个卷积核, 实现了超分辨率色度失真补偿, 使用了统一的处理权值, 确保了整个模型内部组成单元的有机融合。**结论** 相关实验结果验证了本文图像重构模型具有良好可靠性、稳定性和高效性。

**关键词:** 卷积神经网络; 超分辨率; 激活函数; 转置卷积; 深度反投影网络模型; 图像重构

中图分类号: TP391.41; TP183; TS80 文献标志码: A 文章编号: 1001-3563(2024)07-0222-12

DOI: 10.19554/j.cnki.1001-3563.2024.07.028

## Image Reconstruction of Super-resolution Distortion Control Based on Convolutional Neural Network

SHU Zhong<sup>1,2</sup>, ZHENG Bo'er<sup>1</sup>

(1. School of Electronic Information Engineering, Jingchu University of Technology, Hubei Jingmen 448000, China;

2. Jingmen Rongmei Network Technology Co., Ltd., Hubei Jingmen 448000, China)

**ABSTRACT:** The work aims to solve problems of poor correlation between functional units, weak completeness of image chromaticity feature extraction, weak distortion control in super-resolution reconstruction, and residual control in sampling process in super-resolution image reconstruction models. By introducing the double activation function into the convolutional neural network model, the compatibility and connectivity between the functional units in the model were improved. A super-resolution distortion control unit was constructed using a dense connected convolutional neural network to perform convolutional compensation operations on four chromatic components, respectively. The residual interpolation function was applied to the upsampling unit and deep backprojection network rules were used to achieve super-resolution chromaticity feature interpolation operations. The designed model set combined multiple convolutional kernels internally to achieve super-resolution chromaticity distortion compensation. A unified processing weight was used to ensure the organic fusion of the internal components of the entire model. In conclusion, the relevant experimental results verify that the image reconstruction model proposed in this paper has good reliability, stability, and efficiency.

**KEY WORDS:** convolutional neural networks; super resolution; activation function; transposed convolution; deep back-projection networks (DBPN); image reconstruction

早期的图像压缩失真恢复方法通常以最近邻域法和线性插值法为基础并加以相应的改进,其失真恢复结果并不理想,以伪彩色和边缘锯齿效应等现象表现最为突出<sup>[1]</sup>。随着残差插值方法<sup>[2-5]</sup>的提出,对基于伪彩色和边缘锯齿效应的图像压缩失真现象起到较好的约束作用。近些年来,随着深度学习字典在压缩图像重构领域的广泛应用,特别是应用卷积神经网络 (Convolutional Neural Networks, CNN) 通过设计 2 个或 3 个阶段的图像色度参数控制<sup>[6-8]</sup>,进行压缩编码失真恢复处理;还有通过残差插值与 CNN 结合的压缩编码失真控制<sup>[9-11]</sup>、超分辨率 (Super-Resolution) 图像处理机制与 CNN 结合的压缩编码失真控制<sup>[12-14]</sup>等压缩图像重构方法等。

以上基于残差插值、基于 CNN 模型应用和基于超分辨率处理三大类图像重构方法,处理机制的总体思想在本质上是—致的,都是以 G 分量为首要突破口,充分利用 G 颜色分量的失真控制恢复经验,指导其他颜色分量进行恢复重构。3 种方法只关注了—下采样过程在图像重构中的重要性,忽视了对上采样过程的影响因素。其中,基于残差插值的图像重构过度依赖复杂的数学模型运算,忽略了对机器学习模型存在优势的充分利用。基于 CNN 模型应用和基于超分辨率处理 2 种图像重构方法则过度依赖 CCN 网络模型的结构优势,将色彩空间转换采样处理和图像重构处理融合在一起,使得 CCN 网络模型结构过度复杂。以上因素的存在,是本文开展相关研究的依据。

本文结合对基于残差插值和基于深度学习的压缩编码图像重构原理的分析,以卷积神经网络为处理平台,制定压缩编码图像重构策略。主要的研究目标包括:减小卷积神经网络模型的构建复杂度,提高处

理效率;对图像边缘特征提取的损失进行有效控制,提高图像边缘特征的描述准确性;在图像重构的边缘特征映射策略中,引入多次上采样策略,提高上采样图像像素采集的准确度;选取上采样提取的有效图像边缘特征实现图像重构。

## 1 本文图像重构模型构建

### 1.1 模型总体架构

通过对当前经典的压缩图像重构和失真控制策略进行分析,本文提出的压缩编码图像重构模型,重点考虑 2 个方面的因素:由于图像压缩编码后存在亮度和色度失真,因此压缩图像重构消除失真影响最有效的环节应在上采样之前;由于卷积神经网络模型的层次结构丰富,具有较大的可扩展性,在应用中会出现失真残差值的梯度过度增大或梯度完全消失 2 种情况,将超分辨率图像处理策略应用于残差计算,可以大幅简化卷积神经网络的层次结构。本文设计的基于卷积神经网络的超分辨率失真控制重构模型 (Convolutional Neural Networks Super Resolution Model, CNN-SR-M) 处理流程如图 1 所示。

CNN-SR-M 模型的输入端可以接收压缩编码后的  $RG_1G_2B$  色彩模式的图像,以便于与 Bayer-CFA 图像的编码颜色模式匹配;输出端的图像重构结果为 RGB 颜色模式,可确保重构的图像广泛应用于计算机系统 and 网络传输中。CNN-SR-M 模型的主体处理部分由图像色度特征提取单元、超分辨率失真控制单元、上采样单元和色度特征融合单元 4 个模块组成。其中,图像色度特征提取单元负责对  $RG_1G_2B$  色彩空间

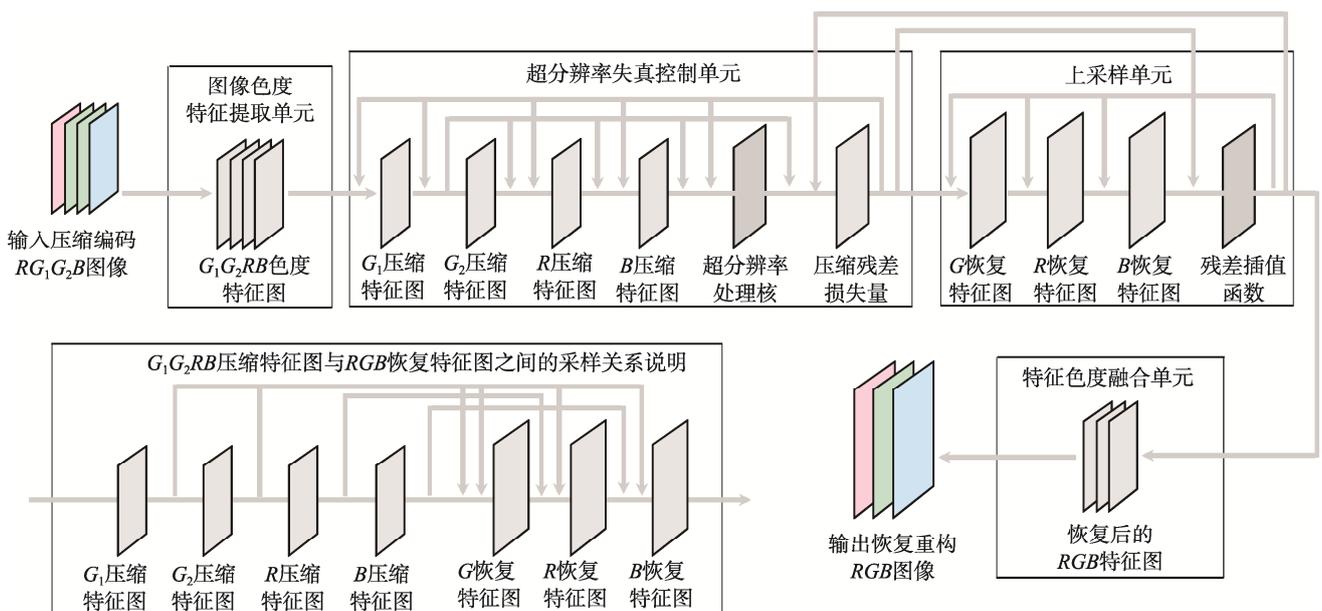


图 1 基于卷积神经网络的超分辨率失真控制重构模型处理流程

Fig.1 Process flow diagram of super-resolution distortion control reconstruction model based on convolutional neural network

图像的4个色度特征进行提取,生成颜色通道灰度边缘特征图,灰度边缘特征为高频信息,这是图像压缩编码中最容易损失的信息,也是与图像噪声之间容易产生混淆的信息,更是图像超分辨率处理重点需要处理的信息。超分辨率失真控制单元实际上就是一个  $G_1$ 、 $G_2$ 、 $R$ 、 $B$  色度分量的残差密度获取模块,所设计的超分辨率处理核将作用于4个色度分量特征,并计算出4个色度分量特征在重构图像时需要补偿的特征残差损失量。首先通过CNN模型完成对  $G_1$  和  $G_2$  2个色度分量特征的处理,通过参考CNN模型对  $G_1$  和  $G_2$  的训练结果,将训练结果获取的控制参数应用于  $R$  和  $B$  2个色度分量特征的处理过程中,是整个模型进行失真控制的核心部分。上采样单元负责完成对  $RG_1G_2B$  和  $RGB$  色彩空间的特征图之间的转换,可对转换后的  $RGB$  特征图存在的损失量进行补偿,同样是整个模型完成失真补偿的核心部分。色度特征融合单元是将通过补偿后的  $RGB$  特征图融合在一起,以便通过CNN模型完成对  $RGB$  图像的重构。

## 1.2 模型构建

### 1.2.1 图像色度特征提取单元

CNN-SR-M 模型各功能单元内部结构和处理策略如下:

图像色度特征提取单元使用 LeNet-5<sup>[15]</sup>作为基本的CNN模型,通过卷积运算提取图像色度特征,省去 LeNet-5 中的池化、全连接层结构,该单元可以提取图像各颜色通道的边缘特征信息,本质上就是对边缘特征进行残差补偿的信息。色度特征提取使用的卷积核激活函数采用 Rectified Linear Unit (ReLU)<sup>[16]</sup>,ReLU 优于 CNN 模型中常用的 Sigmoid 和 Tanh 激活函数。ReLU 的计算方法简单,通过设计有效的阈值就可以控制神经元的开启,不需要进行复杂的导数求极值运算,还可以获取产生色度边缘信息的稀疏特征;由于 ReLU 可以引入多个图像样本参与模型进行训练,可以防止出现误差过大产生的过拟合现象,避免了与正则化(Dropout)结合时所造成的兼

容性差等问题。色度特征提取单元设计了2个卷积层,设定第2个卷积核的数量为第1个卷积核的2倍。定义图像色度特征提取的输出为  $O(RG_1G_2B)$ ,压缩编码图像的输入为  $I(RG_1G_2B)$ ,使用 ReLU 的激活函数的卷积层为  $f(r)$ ,Sigmoid 激活函数卷积层为  $f(cnn)$ 。本文保留原始 CNN 模型中的 Sigmoid 激活函数卷积层  $f(cnn)$ 的原因是以保证 CNN 模型结构设计的一致性,便于与 CNN-SR-M 模型中其他功能单元建立联系,防止各功能单元之间完全独立,影响各单元之间的兼容性连接。图像色度特征提取单元的主要运算规则为:

$$\begin{aligned} O(RG_1G_2B) &= f(cnn)(f(r)I(RG_1G_2B)), \\ O(RG_1G_2B) &= \max(0, I(RG_1G_2B)) \end{aligned} \quad (1)$$

### 1.2.2 超分辨率失真控制单元

在超分辨率失真控制单元中,引用密集连接卷积神经网络模型(Densely Connected Convolutional Networks, DenseNet)的结构框架,与图像色度特征提取单元匹配,该单元也是由卷积层组成,使用 Leaky ReLU 激活函数和 Sigmoid 激活函数设计2类卷积层。定义其卷积层为  $f(lr)$ ;使用 Sigmoid 激活函数的卷积层与图像色度特征提取单元中的定义完全相同。超分辨率失真控制单元内部密集连接卷积层组成结构及处理流程如图2所示。

图2为由于4个基本子单元组成的 DenseNet 模型,4个基本子单元针对  $RG_1G_2B$  的4个色度分量,失真补偿运算的卷积核心为 Leaky ReLU 激活函数,其卷积层表示为  $f(lr)$ ,每个子单元的处理权值  $\alpha = \frac{1}{5}$ , $\alpha$  的取值在后文进行了相关实验进行确定,在卷积补偿运算中还得到了3个中间输出量  $O(1)$ 、 $O(2)$ 、 $O(3)$ 。其中, $O(1)$ 与  $G_1$ 、 $G_2$  的残差补偿相关,同时关联了输入量  $I(RG_1G_2B)$ ;  $O(2)$ 与  $R$  的残差补偿、 $O(1)$ 、 $I(RG_1G_2B)$  相关;  $O(3)$ 与  $B$  的残差补偿、 $O(1)$ 、 $O(2)$ 、 $I(RG_1G_2B)$  相关。定义超分辨率处理的输出结果为  $O'(RG_1G_2B)$ ,超分辨率失真控制单元的主要运算过程为:

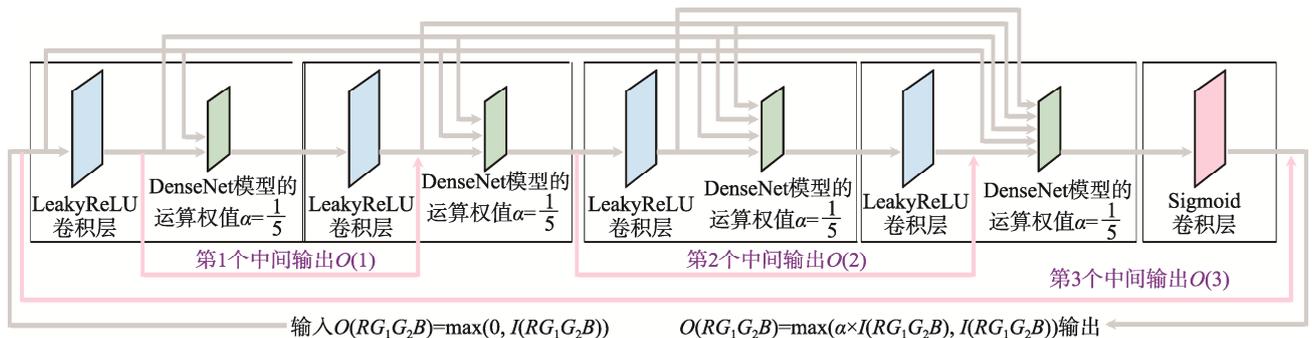


图2 超分辨率失真控制单元的内部组成结构和处理流程

Fig.2 Internal composition structure and processing flow diagram of super-resolution distortion control unit

$$\begin{aligned}
 O(RG_1G_2B) &= \max(\alpha \times I(RG_1G_2B), I(RG_1G_2B)) \\
 O'(RG_1G_2B) &= f(cnn)(O(RG_1G_2B), f(lr)O(RG_1G_2B), \\
 &\quad O(1), O(2), O(3)) + \alpha \times I(RG_1G_2B) \\
 O(1) &= f(lr)(I(RG_1G_2B), f(lr)I(RG_1G_2B)) + \\
 &\quad \alpha \times f(lr)I(RG_1G_2B) \\
 O(2) &= f(lr)(I(RG_1G_2B), f(lr)I(RG_1G_2B), O(1)) \\
 O(3) &= f(lr)(I(RG_1G_2B), f(lr)I(RG_1G_2B), \\
 &\quad O(1), O(2)) + \alpha \times O(1)
 \end{aligned} \tag{2}$$

### 1.2.3 上采样单元

上采样单元的核心目标为将压缩编码后的  $RG_1G_2B$  图像映射为失真补偿后的重构  $RGB$  图像, 包括制定  $RG_1G_2B$  向  $RGB$  色彩空间转换的上采样策略、 $RGB$  向  $RG_1G_2B$  色彩空间转换的下采样策略、设计上采样残差插值函数等过程, 关键是将残差插值函数应用于上采样中。在上采样中, 需要对生成的  $R$ 、 $G$ 、 $B$  3 个分量色度特征进行超分辨率处理, 针对空间坐标维度的扩大, 不仅要提高 3 个分量色度特征图的维度 (纵横 2 个方向的尺寸), 还要对增加的空间坐标维度的像素点进行特征值插值, 特征插值就是通过残差插值函数完成的。上采样单元通过设计一个卷积层

$f(\alpha)$  用于上、下采样的信息交换, 主要是获取上采样和下采样的权重分配控制参数, 特别是上采样对色度特征的增强控制; 设计一个转置卷积层  $f(T)$ , 主要用于上采样过程对各个色度分量特征的维度进行扩大, 对下采样过程各个色度分量特征的维度进行缩小。除引入一个 Sigmoid 卷积层  $f(cnn)$  与整个 CNN-SR-M 模型其他功能单元建立联系外,  $f(\alpha)$  和  $f(T)$  卷积层使用 Parametric Rectified Linear Unit (PReLU) 作为激活函数。使用 PReLU 激活函数的原因主要是充分应用了其更强的自适应性, 实现对处理权值  $\alpha$  的灵活控制。依据以上对上采样单元主要功能的论述, 在设计的上采样单元中应包含上采样子单元、下采样子单元、残差插值函数和 Sigmoid 卷积层, 其总体结构如图 3a 所示, 上采样子单元和下采样子单元的内部结构如图 3b 和图 3c 所示。

本文上采样色度特征图维度扩展选择了转置卷积 (Transposed Convolution) 实现拼接, 转置卷积根据对卷积运算核的维度控制, 实现色度特征的维度进行扩展, 其扩展只涉及特征图的维度, 与特征图的值无关; 同时, 可以非常方便地在基于 CNN 的模型中进行部署。上采样色度特征值的插值运算选择了深度

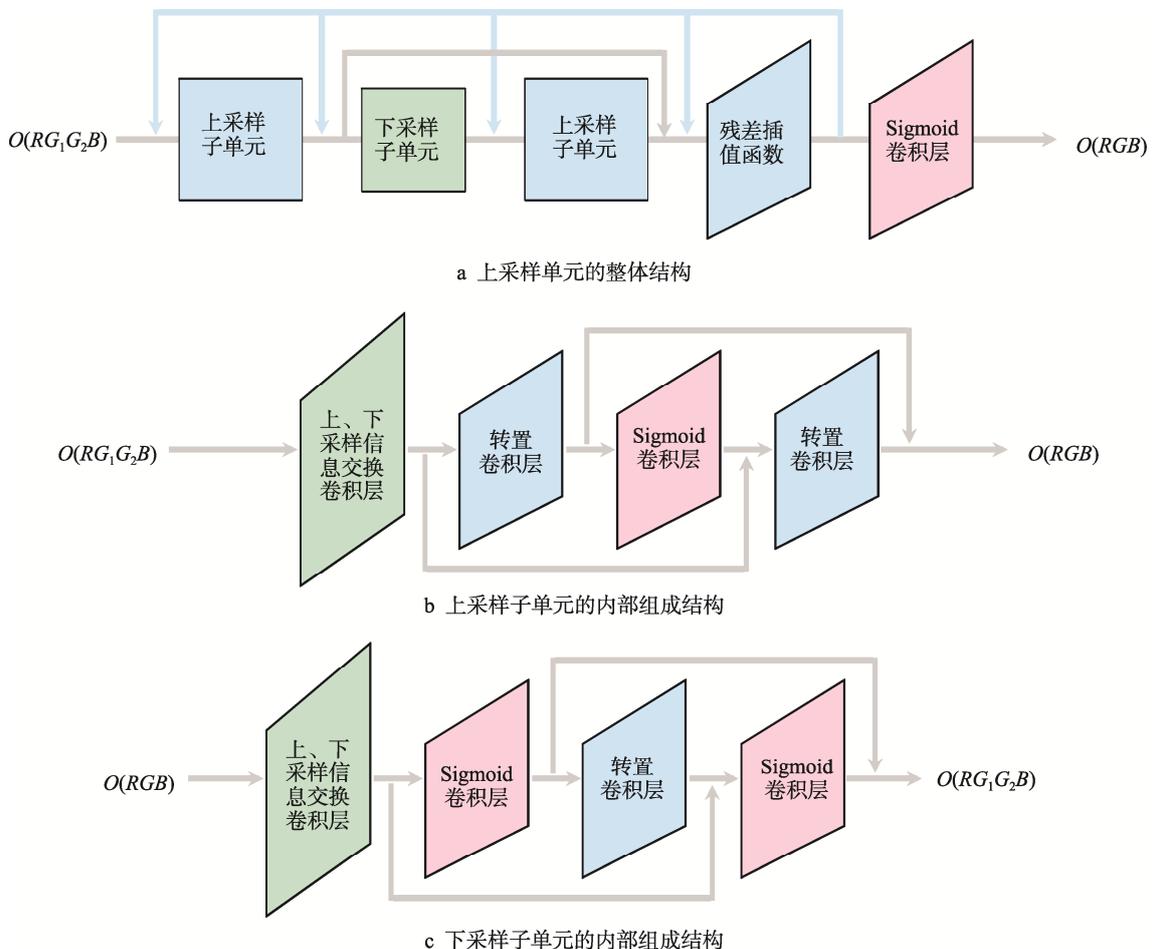


图 3 上采样单元的组成结构和处理流程

Fig.3 Overall composition structure and processing flow diagram of upsampling unit

反投影网络 (Deep Back-Projection Networks, DBPN) 方法。DBPN 插值方法同时针对上采样和下采样 2 个过程进行迭代运算, 依据前一次迭代运算产生的采样误差, 对下一次迭代运算进行修正, 在 CNN 等机器学习模型中实现对误差的最小化控制。图 3 所示的上采样单元设计, 应用转置卷积拼接进行超分辨率色度特征图空间扩展, 应用 DBPN 插值运算进行超分辨率色度特征插值运算。

依据图 3 所示的上采样单元处理流程, 针对上采样和下采样子单元, 在定义  $f(\alpha)$  和  $f(T)$  卷积层的基础上, 还需要定义一个下采样子单元卷积层  $f(q)$ , 在此,  $f(T)$  转置卷积层本质上就是上采样子单元卷积层。针对上采样单元的总结构模型, 定义整个上采样单元卷积层为  $f(p)$ , 其卷积核使用 PReLU 作为激活函数; 定义上采样子单元为  $F(T)$ , 以转置卷积运算为核心; 定义下采样子单元为  $F(q)$ , 激活函数同为 PReLU。上采样单元的处理过程可以表示为:

$$\begin{aligned} O(RGB) &= f(T)\{f(q)[f(T)(f(\alpha)O'(RG_1G_2B))] - \\ &\quad f(\alpha)O'(RG_1G_2B)\} + f(T)[f(\alpha)O'(RG_1G_2B)] \\ O'(RGB) &= f(p)\{F(T)O(GB), \\ &\quad F(T)[F(q)(F(T)O(GB))]\} \end{aligned} \quad (3)$$

在式 (3) 中,  $O(GB)$  为上采样和下采样子单元处理后的  $RGB$  特征图,  $O'(RGB)$  为上采样单元经过超分辨率处理后的  $RGB$  特征图。在上采样单元色度特征图维度扩展时, 其输出色度特征图维度是输入色度特征图维度的 2 倍。在上采样单元色度特征值的插值运算中, 按 4 邻域规则分割色度特征图为  $8 \times 8$  的特征子图, 对相邻特征子图的变化值进行计算, 构建残差插值函数。定义相邻特征子图之间的特征量变化值为  $A$ , 不相邻特征子图之间的特征量变化值为  $B$ , 相邻特征子图中的像素有  $M$  个, 不相邻特征子图中的像素有  $N$  个; 定义相邻的正常无损子图像为  $x_1(i, j)$ , 压缩编码后的相邻子图像为  $y_1(i, j)$ , 对  $y_1(i, j)$  进行理想重构的子图像为  $y_1'(i, j)$ ; 不相邻的正常无损子图像为  $x_2(i, j)$ , 压缩编码后的不相邻子图像为  $y_2(i, j)$ , 对  $y_2(i, j)$  进行理想重构的子图像为  $y_2'(i, j)$ ; 设定残差插值函数为  $K$ , 残差插值控制权重为  $\alpha$ , 则上采样单元色度特征插值的运算过程可表示为:

$$\begin{aligned} A &= \frac{\sum_{i=1, j=1}^{M, M} (x_1(i, j) - y_1(i, j))^2 + \sum_{i=1, j=1}^{M, M} (x_1(i, j) - y_1'(i, j))^2}{M} \\ B &= \frac{\sum_{i=1, j=1}^{N, N} (x_2(i, j) - y_2(i, j))^2 + \sum_{i=1, j=1}^{N, N} (x_2(i, j) - y_2'(i, j))^2}{N} \end{aligned} \quad (4)$$

$$K = \alpha \times (A - B)$$

在式 (4) 中, 当  $A > B$  时,  $\alpha = \log_{10} \frac{M}{\min(M, N)}$ ; 当  $A \leq B$  时,  $\alpha = 0$ 。

## 1.2.4 色度特征融合单元

色度特征融合单元的主要功能是将经过上采样单元完成失真补偿后特征图映射为  $RGB$  图像, 也就是依据图像特征重构完整图像, 其实现方法也较为简单。本文方法是在 CNN 模型中通过构建卷积层直接完成。

## 2 实验与讨论

### 2.1 实验方案

本文实验使用的计算机处理器为 AMD Ryzen 5 5600G with Radeon Graphics 3.90 GHz, 内存为 16.0 GB, 操作系统为 Windows10, 64 位, 使用的实验软件为 Matlab2014a。实验选用 LeNet-5 模型作为卷积神经网络的预训练模型, 使用 Stanford Dogs Dataset 犬类图像数据集、CompCars 汽车类图像数据集、Flowers 花卉类图像数据集、Home Objects 客厅类图像数据集作为模型的测试数据集, 以提高构建模型的泛化精度。LeNet-5 模型的输入层—隐层—输出层的节点分配分别为 10—6—1。其中, 隐层中第 1 层的神经元设置为 8 个, 后续层神经元设置为  $8^n$  递增; 最小训练速度为 0.9, 尽量取最大值, 但能够保持训练过程的权重分配变化和收敛变化适中; 模型训练的迭代次数设置为 100, 迭代步长为 1。预训练模型通过对以上 3 个图像数据集进行训练, 完成模型的正则化, 验证以上超参数设置的准确性, 确保实验中重构图像的可靠性和准确性。

实验内容主要包括: 在超分辨率失真控制单元中, 对选择 Leaky ReLU 和 ReLU 激活函数构建卷积核的性能进行比较验证, 对选择 LeNet-5 模型和 DenseNet 模型构建卷积网络模型的性能进行比较验证, 对构建模型的处理权重  $\alpha$  的取值进行验证; 在上采样单元中, 对选择张量拼接和转置卷积 2 种上采样色度特征图维度扩展方法进行比较分析, 对选择渐进式采样和深度反投影网络 2 种上采样色度特征插值方法进行比较分析; 本文设计的 CNN-SR-M 模型与文献[3]、文献[8]、文献[11]、文献[17]和文献[18] 5 种经典和较新的图像重构失真控制方法进行比较分析。实验结果评价指标详见以上实验中的相关论述。

## 2.2 结果与讨论

### 2.2.1 超分辨率失真控制性能评价

针对超分辨率失真控制单元, 本文设计实验对选择 Leaky ReLU 和 ReLU 激活函数构建卷积核、选择基本 LeNet-5 和 DenseNet 模型构建卷积网络模型的失真控制效果进行比较验证; 同时, 对构建的卷积网络模型的处理权重  $\alpha$  的准确选取进行验证。实验评价

指标为色度特征补偿率、色度特征峰值信噪比 (PSNR) 和色度边缘特征图。其中, 定义压缩编码后色度特征值为  $p_1$ , 压缩编码失真补偿后的特征值为  $p_2$ , 未经过压缩编码的原图像特征值为  $p_3$ , 则色度特征补偿率  $p$  的计算式为  $p=(p_2-p_1)/p_3$ 。  $p$  值越大, 说明失真控制效果越好。定义压缩编码特征图为  $p_1(i, j)$ , 压缩编码失真补偿后的特征图为  $p_2(i, j)$ , 色度特征峰值信噪比  $P_{PSNR}$  的计算公式为:

$$P_{PSNR} = 10 \times \log_{10} \left( \frac{1}{L_{MSE}} \right),$$

$$L_{MSE} = \sum_{i=0}^M \sum_{j=0}^N \|p_2(i, j) - p_1(i, j)\|^2 / M \times N$$
(5)

式中: 分子 1 表示色度特征的最大值为 1;  $L_{MSE}$  为均方误差;  $M \times N$  为特征图的维度;  $\|\cdot\|^2$  为特征图向量膜的平方。本文实验设定  $P_{PSNR} \geq 35$  为理想值。色度边缘特征图指经过超分辨率失真控制单元对失真进行补偿后的特征图。针对 DenseNet 模型, 分别选取  $\alpha$  的值为 0.0~1.0, 对失真补偿后特征图的  $P_{PSNR}$  进行统计, 同样取  $P_{PSNR} \geq 35$  为理想值。实验测试数据如表 1~3 和图 4 所示。

在表 1~3 统计的实验数据中, 使用 Leaky ReLU 激活函数构建 DenseNet 模型时, 对失真补偿的信息最多, 通过使用高斯平滑滤波器对失真补偿后的色度特征图进行检测, 补偿信息均为有效高频信息, 不存在噪声。失真补偿后的色度特征图的  $P_{PSNR}$  也在 35 以上,

表 1 使用不同激活函数和卷积网络模型的色度特征补偿统计数据

Tab.1 Statistical data on chromaticity feature compensation using different activation functions and convolutional network models

激活函数与卷积模型	色度特征补偿率 P/%			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
ReLU+LeNet-5	1.51	1.62	1.40	1.55
ReLU+DenseNet	12.27	12.29	12.94	12.58
Leaky ReLU+ LeNet-5	9.05	9.12	9.20	9.07
Leaky ReLU+ DenseNet	<b>24.69</b>	25.17	24.90	24.86

表 2 使用不同激活函数和卷积网络模型的失真控制质量评价数据

Tab.2 Quality evaluation data for distortion control using different activation functions and convolutional network models

激活函数与卷积模型	$P_{PSNR} (\geq 35 \text{ 为有效})$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
ReLU+ImageNet	12.44	13.05	13.17	12.94
ReLU+DenseNet	21.80	21.65	21.59	21.33
Leaky ReLU+ ImageNet	19.17	18.85	19.02	18.85
Leaky ReLU+ DenseNet	<b>38.05</b>	<b>38.27</b>	<b>37.94</b>	<b>37.86</b>

表 3 使用不同卷积权重对色度特征失真补偿控制的质量评价数据

Tab.3 Quality evaluation data on chromaticity feature distortion compensation control using different convolutional weights

DenseNet 模型使用权值 $\alpha$	$P_{PSNR} (\geq 35 \text{ 为有效})$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
0.0	8.85	9.07	8.94	8.91
0.1	29.71	30.10	28.96	29.07
0.2	38.05	38.27	37.94	37.86
0.3	36.19	36.07	35.97	35.85
0.4	34.27	34.29	33.85	33.92
0.5	30.35	31.07	31.11	30.95
0.6	29.13	28.92	28.85	29.01
0.7	25.52	25.90	25.17	25.22
0.8	21.44	21.85	21.04	21.14
0.9	18.80	18.69	18.73	18.50
1.0	16.66	16.42	16.37	16.25

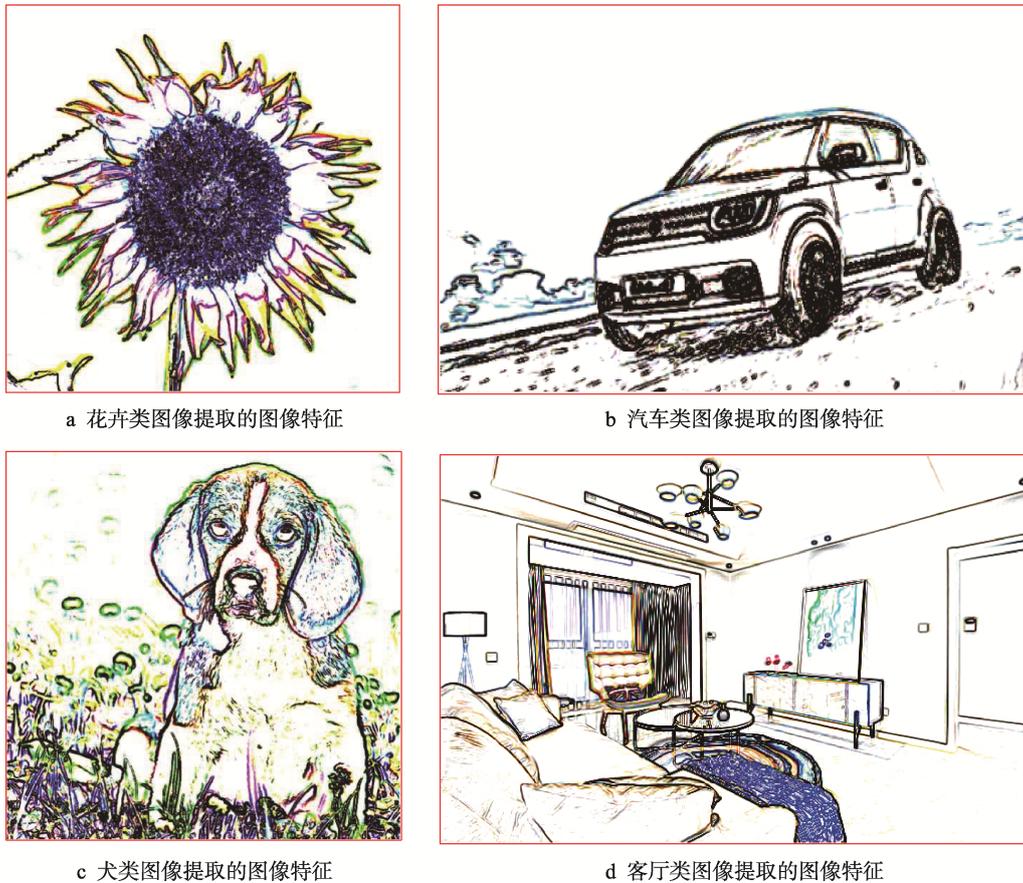


图4 使用 Leaky ReLU 激活函数构建 DenseNet 模型采集的图像色度边缘特征图  
 Fig.4 Building of chromaticity edge feature map of the image captured by DenseNet model through Leaky ReLU activation function

由于针对的检测对象为图像特征信息，因此，设定的  $P_{PSNR}$  的有效值为  $\geq 35$ ，如果是针对完整的图像， $P_{PSNR}$  的有效值应为  $\geq 40$ 。在 DenseNet 模型使用权值的检测中，当  $\alpha=0$  时，统计数据表明，处理过程不仅没有对失真进行补偿，还造成了色度特征的大量损失；当  $\alpha=0.2$  和  $\alpha=0.3$  时，失真补偿后的色度特征图的  $P_{PSNR}$  均在 35 以上， $\alpha=0.2$  时效果最佳；当  $\alpha=0.2\sim 0.8$  时，起到了色度特征补偿的作用，且补偿效果依次下降；当  $\alpha=0.9$  和  $\alpha=1.0$  时，也会造成色度特征的小幅损失。表 1 统计的实验数据直观地体现了本文设计的超分辨率失真控制单元，起到了色度特征补偿的作用，在多个不同类型的图像测试中，其失真补偿控制具有良好的可靠性和稳定性。

### 2.2.2 上采样色度特征维度扩展与色度特征插值性能评价

针对本文设计的上采样单元，从图像色度特征图的维度扩展和对扩展的色度特征插值使用的方法进行实验检测。特征图维度扩展选用了张量拼接方法与本文采用的转置卷积方法进行实验比较，色度特征插值选择了渐进式采样和本文使用的深度反投影网络方法进行实验比较。由于上采样单元最终完成了对压缩编码图像的重构，因此，实验评价的对象针对图像

本身，而不是图像的特征。实验评价的指标主要是平均误差  $\overline{e(i, j)}$  和结构相似度 SSIM (Structural Similarity Index Measure) [19]。其中，定义一个正常无损图像为  $x(i, j)$ ，压缩编码后的图像为  $y(i, j)$ ，对  $y(i, j)$  使用本文策略得到的理想重构图像为  $y'(i, j)$ ，则图像重构失真控制有效的结果可以表示为  $\|x(i, j)-y'(i, j)\|^2 < \|x(i, j)-y(i, j)\|^2$ ，图像重构失真控制无效的结果可以表示为  $\|x(i, j)-y'(i, j)\|^2 > \|x(i, j)-y(i, j)\|^2$ 。定义有效失真控制与无效失真控制的平均误差为  $\overline{e(i, j)}$ ，则有：

$$\overline{e(i, j)} = (\|x(i, j)-y(i, j)\|^2 - \|x(i, j)-y'(i, j)\|^2) - (\|x(i, j)-y'(i, j)\|^2 - \|x(i, j)-y(i, j)\|^2) \quad (6)$$

$$0 \leq \overline{e(i, j)} \leq 1$$

其中， $\|\cdot\|^2$  表示图像向量模的平方。 $\overline{e(i, j)}$  的值越小，说明图像重构失真控制的效果越好，反之，说明图像重构失真控制的效果越差； $\overline{e(i, j)}$  值也可以作为模型神经元激活函数和损失函数的性能评价参数，是评价这 2 个函数收敛性的重要指标之一。定义未经过压缩编码前的原图像为  $x(i, j)$ ，压缩编码后完成失真控制重构图像为  $y'(i, j)$ ，结构相似度 SSIM 指标的主要评价标准

为:  $SSIM(y'(i, j), x(i, j))=SSIM(x(i, j), y'(i, j))$  和  $0 \leq SSIM(y'(i, j)) \leq 1$ 、 $0 \leq SSIM(x(i, j)) \leq 1$ , 能够满足以上标准的实验统计结果表示为 yes, 不能满足以上标准的

实验统计结果表示为 no;  $SSIM(y'(i, j))$  的值越大, 完成失真控制后的重构图像质量越好。实验测试数据如表 4~7 所示。

表 4 使用不同上采样维度扩展和色度特征插值组合的重构图像与原图像平均误差检测结果

Tab.4 Average error detection results of reconstructed images and original images using different upsampling dimension extensions and chromaticity feature interpolation combinations

维度扩展和特征插值方法	$\overline{e(i, j)}$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
张量拼接+渐进式采样	0.58	0.57	0.58	0.59
张量拼接+深度反投影	0.25	0.26	0.23	0.24
转置卷积+渐进式采样	0.46	0.44	0.43	0.46
转置卷积+深度反投影	<b>0.11</b>	<b>0.12</b>	<b>0.10</b>	<b>0.13</b>

表 5 使用不同上采样维度扩展和色度特征插值组合的原图像与重构图像 SSIM 值有效性检测结果

Tab.5 Effectiveness detection results of SSIM values for original and reconstructed images using different upsampling dimension extensions and chromaticity feature interpolation combinations

维度扩展和特征插值	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
张量拼接+渐进式采样	yes	yes	yes	yes
张量拼接+深度反投影	yes	yes	yes	yes
转置卷积+渐进式采样	yes	yes	yes	yes
转置卷积+深度反投影	yes	yes	yes	yes

注: 如果满足  $0 \leq SSIM(x(i, j)) \leq 1$ 、 $0 \leq SSIM(y'(i, j)) \leq 1$  即为 yes, 否则为 no。

表 6 使用不同上采样维度扩展和色度特征插值组合的原图像与重构图像 SSIM 值对称性检测结果

Tab.6 Detection results of SSIM value symmetry between original and reconstructed images using different upsampling dimension extensions and chromaticity feature interpolation combinations

维度扩展和特征插值	人手	动物	花卉	水果
张量拼接+渐进式采样	no	no	no	no
张量拼接+深度反投影	no	no	no	no
转置卷积+渐进式采样	no	no	no	no
转置卷积+深度反投影	<b>yes</b>	<b>yes</b>	<b>yes</b>	<b>yes</b>

注: 如果满足  $SSIM(y'(i, j), x(i, j))=SSIM(x(i, j), y'(i, j))$  即为 yes, 否则为 no。

表 7 使用不同上采样维度扩展和色度特征插值组合的重构图像 SSIM 值检测结果

Tab.7 Reconstructed image SSIM value detection results using different upsampling dimension extensions and chromaticity feature interpolation combinations

维度扩展和特征插值	$SSIM(y'(i, j))$ 值			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
张量拼接+渐进式采样	0.47	0.45	0.45	0.46
张量拼接+深度反投影	0.69	0.67	0.66	0.67
转置卷积+渐进式采样	0.57	0.59	0.58	0.56
转置卷积+深度反投影	<b>0.91</b>	<b>0.93</b>	<b>0.92</b>	<b>0.94</b>

表 4~7 统计的数据表明,在不同类型的图像检测中,检测的  $\overline{e(i, j)}$  值均在 90%以上,且取值相差不大,说明构建的卷积层性能优良,且运行稳定。无论采用哪种维度扩展和特征插值的组合,其 SSIM 的取值都在 [0, 1] 内,不仅说明了选用 SSIM 指标进行图像重构进行评价具有较高的可靠性,也验证了本文设计的上采样单元具有良好的图像重构效果。只有在选择转置卷积和深度反投影网络构建卷积层时,才能检测到 SSIM 评价指标具有对称性的特征。同时,SSIM 的值在不同类型图像的检测中也达 90%以上,进一步验证了本文设计的上采样单元具有良好的可靠性和稳定性。综合对表 4~7 统计的数据分析,也验证了深度反投影网络插值比转置卷积特征维度扩展更为重要。采用转置卷积进行色度特征图维度扩展,结合使用深度反投影网络构建卷积层,具有良好的压缩编码图像重构效果。

### 2.2.3 图像重构失真控制性能评价

实验通过与文献[3]、文献[8]、文献[11]、文献[17]和文献[18] 5 种经典和较新的图像重构失真控制方法进行比较分析,验证 CNN-SR-M 模型的整体性能。

实验使用输入图像和重构图像之间的标准差  $STD(X, Y)$ 、平均梯度比  $\nabla^2 G(X, Y)$ 、复合峰值信噪比 (Composite Peak Signal to Noise Ratio, CPSNR)、基于视觉敏感度检测的结构相似度 SS-SSIM 和图像重构完成的运行时间  $t$  作为图像重构失真控制性能和效率的评价指标。为了体现实验具有的公平性,统一使用 LeNet-5 构建卷积网络模型。模型中常规控制参数一致,在图像样本特征提取和图像重构等方面,调用相关文献和本文提出的算法,并保留算法中关键的控制参数。本实验测试数据如表 8~12 所示。

$STD(X, Y)$  可以精确描述原始输入图像像素灰度值与图像重构之间的离散程度,  $STD(X, Y)$  的值越大,说明重构图像的灰度级分布越分散,重构的图像质量越好,其有效取值为 [0, 1]。平均梯度值比  $\nabla^2 G(X, Y)$  可以准确反映图像中边缘特征存在的反差,其值越大,说明图像重构的清晰度越高,图像重构的质量越好,其有效取值为 [0, 1]。平均梯度值比的计算,采用二阶微分运算对水方向  $i$  和垂直方向  $j$  的在图像全部像素点求梯度值。 $STD(X, Y)$  和  $\nabla^2 G(X, Y)$  2 个标准

表 8 6 种图像重构失真控制方法的输入图像和重构图像之间标准差测试统计结果

Tab.8 Statistical results of standard deviation test between input image and reconstructed image for six image reconstruction distortion control methods

图像重构失真控制方法	$STD(X, Y)$ 值( $0 \leq STD(X, Y) \leq 1$ )			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
文献[3]使用方法	0.78	0.76	0.77	0.75
文献[8]使用方法	0.79	0.78	0.80	0.79
文献[11]使用方法	0.82	0.81	0.82	0.80
文献[17]使用方法	0.83	0.83	0.81	0.83
文献[18]使用方法	0.87	0.85	0.86	0.85
本文 CNN-SR-M 模型方法	<b>0.92</b>	<b>0.93</b>	<b>0.91</b>	<b>0.90</b>

表 9 6 种图像重构失真控制方法的输入图像和重构图像之间平均梯度比测试统计结果

Tab.9 Statistical results of average gradient ratio test between input image and reconstructed image for six image reconstruction distortion control methods

图像重构失真控制方法	$\nabla^2 G(X, Y)$ 值( $0 \leq \nabla^2 G(X, Y) \leq 1$ )			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
文献[3]使用方法	0.64	0.65	0.62	0.64
文献[8]使用方法	0.69	0.70	0.69	0.70
文献[11]使用方法	0.73	0.75	0.73	0.72
文献[17]使用方法	0.79	0.77	0.78	0.79
文献[18]使用方法	0.83	0.81	0.82	0.81
本文 CNN-SR-M 模型方法	<b>0.89</b>	<b>0.88</b>	<b>0.87</b>	<b>0.86</b>

表 10 6 种图像重构失真控制方法的复合峰值信噪比测试统计结果

Tab.10 Statistical results of composite peak signal-to-noise ratio test for six image reconstruction distortion control methods

图像重构失真控制方法	$C_{PSNR}(0 \leq C_{PSNR} \leq 1)$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
文献[3]使用方法	0.54	0.53	0.55	0.52
文献[8]使用方法	0.81	0.80	0.83	0.82
文献[11]使用方法	0.82	0.83	0.81	0.84
文献[17]使用方法	0.85	0.84	0.86	0.85
文献[18]使用方法	0.88	0.85	0.87	0.85
本文 CNN-SR-M 模型方法	<b>0.93</b>	<b>0.91</b>	<b>0.92</b>	<b>0.93</b>

表 11 6 种图像重构失真控制方法的视觉敏感度检测结构相似度测试统计结果

Tab.11 Statistical results of visual sensitivity detection structure similarity test for six image reconstruction distortion control methods

图像重构失真控制方法	$S_{SS-SSIM}(0 \leq S_{SS-SSIM} \leq 1)$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
文献[3]使用方法	0.47	0.49	0.48	0.45
文献[8]使用方法	0.55	0.57	0.58	0.56
文献[11]使用方法	0.71	0.70	0.71	0.68
文献[17]使用方法	0.79	0.81	0.80	0.76
文献[18]使用方法	0.82	0.80	0.83	0.79
本文 CNN-SR-M 模型方法	<b>0.89</b>	<b>0.87</b>	<b>0.89</b>	<b>0.88</b>

表 12 6 种图像重构失真控制方法完成图像重构处理时间的测试统计结果

Tab.12 Statistical results of image reconstruction processing time for six image reconstruction distortion control methods

图像重构失真控制方法	运行时间 $t/s$			
	犬类图像数据集 (Stanford dogs dataset)	汽车类图像数据集 (Comp cars)	花卉类图像数据集 (Flowers)	客厅类图像数据集 (Home objects)
文献[3]使用方法	36.52	35.47	36.07	35.85
文献[8]使用方法	74.39	73.54	74.26	73.81
文献[11]使用方法	98.03	95.92	97.44	93.50
文献[17]使用方法	46.51	46.73	45.96	46.39
文献[18]使用方法	40.35	41.17	42.30	41.56
本文 CNN-SR-M 模型方法	<b>14.19</b>	<b>14.52</b>	<b>14.36</b>	<b>14.28</b>

也是整个模型收敛性的重要指标。设定输入图像  $X$  的像素灰度值为  $X(i, j)$ , 重构图像  $Y$  的像素灰度值为  $Y(i, j)$ , 图像维度为  $M \times M$ , 其 2 个性能评价指标可以表示为:

$$STD(X, Y) = \sqrt{\frac{1}{M^2} \sum_{i=0}^{M-1} \sum_{j=0}^{M-1} (Y(i, j) - X(i, j))^2}$$

$$\nabla^2 G(X, Y) = \frac{\frac{1}{M^2} \sum_{i=0}^{M-1} \sum_{j=0}^{M-1} \sqrt{(\nabla^2(i) \times (X(i, j))^2 + \nabla^2(j) \times (X(i, j))^2)}}{\frac{1}{M^2} \sum_{i=0}^{M-1} \sum_{j=0}^{M-1} \sqrt{(\nabla^2(i) \times (Y(i, j))^2 + \nabla^2(j) \times (Y(i, j))^2)}} \quad (7)$$

定义图像的数量为  $K$ , 维度为  $M \times N$ , 未进行压缩编码的原始图像为  $x(i, j)$ , 对压缩编码进行超分辨率补偿的重构图像为  $y'(i, j)$ , CPSNR 的计算方法为:

$$C_{PSNR} = \sum_{i=1}^M \sum_{j=1}^N 10 \times \log_{10} \frac{255^2}{C_{MSE}} / K \quad (8)$$

$$C_{MSE} = \frac{1}{3 \times M \times N} \sum_{i=1}^M \sum_{j=1}^N \|x(i, j) - y'(i, j)\|^2$$

式中:  $C_{MSE}$  为复合均方误差,  $0 \leq C_{MSE} \leq 1$ 。 $C_{PSNR}$  越大, 图像重构的质量越好。

SS-SSIM 评价指标是在结构相似度 SSIM 的基础上定义的, 在 SSIM 基于图像亮度、对比度和图像像

素分布结果比较分析<sup>[19]</sup>的基础上,增加了图像边缘检测和图像重构失真敏感度检测功能,图像边缘使用 Sobel 算子进行检测,采用 8×8 的子块分割统计图像边缘特征,计算失真敏感度,最后计算 SS-SSIM 值,其中,失真敏感度表示图像边缘特征与设定的幂指数之间建立的关系。定义图像分割的块数量为  $K$ ,未进行压缩编码的原始图像为  $x(k)$ ,对压缩编码进行超分辨率补偿的重构图像为  $y'(k)$ , $k \in K$ 。在失真敏感度运算中,需要将以上 2 类图像的边缘特征进行关联,则 2 类图像的边缘特征定义为  $g(x(i, j), y'(i, j))$ ,失真敏感度为  $h(x(i, j), y'(i, j))$ ,设定失真敏感度最大值为  $h_{\max}$ ,最小值为  $h_{\min}$ ,则失真敏感度的计算结果存在 3 种可能:

$$h(x(i, j), y'(i, j)) = h_{\max} - \frac{g(x(i, j), y'(i, j))}{c}$$

$$h(x(i, j), y'(i, j)) = \frac{h_{\max} - h_{\min}}{2} - \frac{g(x(i, j), y'(i, j))}{c} \quad (9)$$

$$h(x(i, j), y'(i, j)) = h_{\min}$$

式中: $c$ 为一个非零常数,与 SSIM 中的  $c$  常数含义相同,可防止  $c=0$  时, $g(x(i, j), y'(i, j))$  的值无法发挥作用。

基于视觉敏感度检测的结构相似度值的计算方法为:

$$S_{SS-SSIM} = \frac{1}{K} \sum_{k=1}^K (SSIM(x(k), y'(k)))^{h(x(i, j), y'(i, j))} \quad (10)$$

式中, $SSIM(x(k), y'(k))$ 的计算方法本文不再列出<sup>[19]</sup>。 $0 \leq S_{SS-SSIM} \leq 1$ ,其取值越大图像重构的失真控制效果越好。

表 8~12 统计的数据非常直观地表明,本文设计的 CNN-SR-M 模型在图像重构的性能、失真控制和处理效率方面都具有一定的优势。

### 3 结语

本文通过对残差插值、残差插值与深度学习融合、残差插值与超分辨率处理融合的压缩编码图像重构原理进行分析,充分复用卷积层在图像色度特征提取方面的优势,结合超分辨率处理在图像色度残差插值失真控制方面的优势,设计了 CNN-SR-M 针对图像压缩编码的重构模型。相关研究工作得出以下结论:

- 1) 图像色彩空间转换中的上采样过程非常重要。
- 2) 压缩编码色度特征残差损失计算处理与色度特征超分辨率强化处理之间需要进行关联,压缩编码色度特征与失真强化色度特征也需要实现相关。
- 3) 图像重构失真控制需要引入去池化处理机制,并对全连接层进行改进。
- 4) 完整的 CNN-SR-M 模型需要保证各功能单元中的激活函数应具有兼容性、处理权重可统一进

行分配。

5) 图像重构上采样特征图维度扩展应采用转置卷积,色度特征值的插值效果可依据峰值信噪比作为评判指标,残差插值函数设计中应包含失真控制残差插值和模型的处理权值。

通过对 CNN-SR-M 模型中 3 个主要组成单元的性能进行实验检测,客观评价指标和主观视觉感受的统计结果表明,本文制定的基于卷积神经网络的超分辨率失真控制图像重构策略,在实际应用中具有良好可靠性、稳定性和高效性。

后续研究工作的主要方向:提高图像色度特征提取的精准性;通过下采样实现图像色度及色度特征的精细划分;强化超分辨率处理与色度失真插值运算之间的关系。

### 参考文献:

- [1] HUA L, XIE L, CHEN H. A Color Interpolation Algorithm for Bayer Pattern Digital Cameras Based on Green Components and Color Difference Space[C]// In Proceedings of the 2010 IEEE International Conference on Progress in Informatics and Computing. New York: IEEE, 2010: 791-795.
- [2] KIKU D, MONNO Y, TANAKA M, et al. Beyond Color Difference: Residual Interpolation for Color Image Demosaicking[J]. IEEE Transactions on Image Processing, 2016, 25(3): 1288-1300.
- [3] MONNO Y, KIKU D, TANAKA M, et al. Adaptive Residual Interpolation for Color and Multispectral Image Demosaicking[J]. Sensors, 2017, 17(12): 2787.
- [4] 夏皓,吕宏峰,罗军,等.图像超分辨率深度学习研究及应用进展[J].计算机工程与应用,2021,57(24): 51-60.  
XIA H, LYU H F, LUO J, et al. Survey on Deep Learning Based Image Super-Resolution[J]. Computer Engineering and Applications, 2021, 57(24): 51-60.
- [5] 王海琳,韩正昊,李力,等.基于残差和高频替换的 SONY-RGBW 阵列彩色重构方法[J].激光与光电子学进展,2021,58(20): 66-78.  
WANG H L, HAN Z H, LI L, et al. Residual and High-Frequency Replacement Based Color Reconstruction Method for SONY-RGBW Array[J]. Laser & Optoelectronics Progress, 2021, 58(20): 66-78.
- [6] TAN R, ZHANG K, ZUO W, et al. Color Image Demosaicking Via Deep Residual Learning[C]// In Proceedings of the 2018 International Conference on Multimedia and Expo. New York: IEEE, 2018: 6-18.
- [7] CUI K, JIN Z, STEINBACH E. Color Image Demo-

- saicking Using a 3-stage Convolutional Neural Network Structure[C]// In Proceedings of the 2018 IEEE International Conference on Image Processing. New York: IEEE, 2018: 2177-2181.
- [8] WANG Y, YIN S, ZHU S, et al. NTSDCN: New Three Stage Deep Convolutional Image Demosaicking Network[J]. IEEE Transactions on Circuits and Systems for Video Technology(Early Access), 2020, 31(9): 3725-3729.
- [9] SHI W, CABALLERO J, HUSZÁR F, et al. Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network[C]// In Proceedings of the 2016 IEEE International Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 1874-1883.
- [10] 汤漫, 杨斌. 基于快速残差插值和卷积神经网络的去马赛克算法[J]. 南华大学学报(自然科学版), 2019, 33(6): 68-76.
- TANG M, YANG B. Efficient Demosaicking Algorithm Based on Residual Interpolation and Convolution Neural Network[J]. Journal of University of South China (Science and Technology), 2019, 33(6): 68-76.
- [11] LIU L, JIA X, LIU J, et al. Joint Demosaicing and Denoising with Self Guidance[C]// In Proceedings of the 2020 IEEE International Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2020: 2240-2249.
- [12] 马昊宇, 徐之海, 冯华君, 等. 基于小递归卷积神经网络的图像超分辨算法[J]. 光子学报, 2018, 47(4): 0410004.
- MA H Y, XU Z H, FENG H J, et al. Image Super-Resolution Based on Tiny Recurrent Convolutional Neural Network[J]. Acta Photonica Sinica, 2018, 47(4): 185-193.
- [13] FENG L, ZHANG X. A Dual-Network-Based Super-Resolution for Compressed High Definition Video[C]// In Proceedings of the 2018 Advances in Multimedia Information Processing. New York: IEEE, 2018: 600-610.
- [14] CHEN H G, HE X H, REN C, et al. CISRDCNN: Super-Resolution of Compressed Images Using Deep Convolutional Neural Networks[J]. Neurocomputing, 2018, 285(4):204-219.
- [15] 王济民, 魏怡, 周宇, 等. 基于 LeNet-5 卷积神经网络和颜色特征的限速标志识别[J]. 计算机科学, 2021, 48(S02): 345-350.
- WANG J M, WEI Y, ZHOU Y, et al. Speed Limit Sign Recognition Based on LeNet-5 CNN and Color Feature[J]. Computer Science, 2021, 48(S2): 345-350.
- [16] CHAITY B, TATHAGATA M, EDUARDO P J. Feature Representations Using the Reflected Rectified Linear Unit(RReLU) Activation[J]. Big Data Mining and Analytics, 2020, 3(2): 102-120.
- [17] 潘泽民, 覃亚丽, 郑欢, 等. 基于深度神经网络的块压缩感知图像重构[J]. 计算机科学, 2022, 49(S2): 510-518.
- PAN Z M, QIN Y L, ZHENG H, et al. Block-Based Compressed Sensing of Image Reconstruction Based on Deep Neural Network[J]. Computer Science, 2022, 49(S2): 510-518.
- [18] 郑铠涛, 李海艳, 甘华权, 等. 基于低秩约束和全变分正则化的 CUP-VISAR 压缩图像重构算法[J]. 强激光与粒子束, 2023, 35(7): 74-82.
- ZHENG K T, LI H Y, GAN H Q, et al. CUP-VISAR Image Reconstruction Based on Low-Rank Prior And-total-Variation Regularization[J]. High Power Laser and Particle Beams, 2023, 35(7): 74-82.
- [19] 黄友文, 唐欣, 周斌. 结合双注意力和结构相似度量的图像超分辨率重建网络[J]. 液晶与显示, 2022, 37(3): 367-375.
- HUANG Y W, TANG X, ZHOU B. Image Super-Resolution Reconstruction Network with Dual Attention and Structural Similarity Measure[J]. Chinese Journal of Liquid Crystals and Displays, 2022, 37(3): 367-375.